

AVALIAÇÃO DA ESTABILIDADE DE TALUDES. DESEMPENHO DAS REDES NEURONAIS VERSUS MÁQUINAS DE VETORES DE SUPORTE

SLOPE STABILITY EVALUATION. PERFORMANCE OF NEURAL NETWORKS VERSUS SUPPORT VECTOR MACHINES

Martins, Francisco Ferreira; *Departamento de Engenharia Civil da Universidade do Minho, Guimarães, Portugal, ffm@civil.uminho.pt*

Miranda, Tiago Filipe da Silva; *Departamento de Engenharia Civil da Universidade do Minho, Guimarães, Portugal, tmiranda@civil.uminho.pt*

RESUMO

Neste trabalho são comparados os desempenhos das Redes Neuronais Artificiais (RNA) com as Máquinas de Vetores de Suporte (MVS) na avaliação da estabilidade de taludes. Para isso foi gerada uma base de dados contendo os fatores de segurança (FS) calculados para 501 taludes homogêneos bem como as suas características geométricas e geotécnicas. Os fatores de segurança foram obtidos usando o método de Bishop modificado e o software SLOPE/W. Nas análises efetuadas foi usada a biblioteca RMiner no ambiente R para facilitar o uso deste nas tarefas de classificação e regressão. Para usar aquela tarefa as bases de dados foram ajustadas substituindo o fator de segurança dos taludes por "estável" quando FS é maior ou igual à unidade e "instável" quando FS é menor que 1. Constata-se que tanto as RNA como as MVS apresentam bons desempenhos nas tarefas de regressão e de classificação. No entanto, são as MVS que apresentam os melhores desempenhos nas duas tarefas.

ABSTRACT

This work compares the performances of the Artificial Neural Networks (ANN) with the Support Vector Machines (SVM) in the slope stability evaluation. For this purpose a database containing the factors of safety (FS) computed for 501 homogeneous slopes as well as their geometric and geotechnical characteristics was generated. The factors of safety were obtained using the modified Bishop method and the SLOPE/W software. The analyses were performed using the RMiner library in the R environment to facilitate its use in classification and regression tasks. In the classification task the data were adjusted by replacing the FS for "stable" when FS is greater or equal to 1 and "unstable" when FS is lower than 1. Both ANN and SVM presented good performances in regression and classification tasks. Nevertheless, the SVM had better performance in both tasks.

1 - INTRODUÇÃO

Este trabalho vem na sequência de trabalhos anteriores do primeiro autor relacionados com a avaliação da estabilidade de taludes através de técnicas de data mining (Martins et al., 2008; Martins e Almeida, 2009; Martins et al., 2010). São duas as evoluções apresentadas em relação aos trabalhos anteriormente publicados. Uma das evoluções tem a ver com o conjunto de dados usados no teste dos modelos. Enquanto nos trabalhos anteriores esse conjunto era também usado no treino, neste trabalho esse conjunto é totalmente desconhecido dos modelos. A segunda evolução tem a ver com a inclusão da tarefa de classificação, para além da regressão. Para usar aquela tarefa as bases de dados foram ajustadas substituindo o fator de segurança dos taludes por "estável" quando FS é maior ou igual à unidade e "instável" quando FS é menor que 1.

No presente trabalho são considerados taludes homogêneos e superfícies de deslizamento circular, sendo usado nos cálculos o método de Bishop modificado. Este método foi escolhido por ser um método simples que conduz a um fator de segurança com um erro em relação a métodos mais rigorosos de análise que, na maioria das situações, é inferior a 2%, e raramente excede os 7% (Craig, 2007).

Em seguida será apresentado o processo de Data Mining, sendo sucintamente descritas as Redes Neuronais Artificiais e as Máquinas de Vectores de Suporte. Serão também apresentadas as medidas usadas para avaliar o desempenho das RNA e MVS e será efetuada a aplicação do processo de Data Mining.

2 - DATA MINING

Nas últimas décadas, os avanços alcançados nos sistemas computacionais têm permitido o desenvolvimento de novas ferramentas que possibilitam a criação e o armazenamento de grandes

volumes de dados. No entanto, como os métodos estatísticos se têm revelado limitados para a deteção de padrões e tendências em bases de dados de elevada complexidade, surgiu a área da Descoberta de Conhecimento em Bases de Dados, que se desdobra essencialmente nas etapas de pré-processamento, Data Mining e pós-processamento. Na etapa do Data Mining são aplicados algoritmos para descobrir padrões e tendências a partir dos dados (Santos e Azevedo, 2005). Entre os algoritmos existentes destacam-se os relacionados com as árvores de decisão (Quinlan, 1986), os k-vizinhos próximos (Hechenbichler e Schliep, 2004), as redes neuronais artificiais (Haykin, 1999) e as máquinas de vetores de suporte (Cortes e Vapnik, 1995).

Todos estes algoritmos já foram anteriormente usados na avaliação da segurança de taludes (Martins et al., 2008; Martins e Almeida, 2009; Martins et al., 2010). No entanto, dado que as RNA e as MVS conduziram aos melhores resultados, estas foram usadas no presente trabalho.

2.1 - Redes neuronais artificiais e máquinas de vetores de suporte

Uma vez que as RNA e as MVS já foram anteriormente apresentadas pelo primeiro autor deste trabalho (Martins et al., 2008; Martins e Almeida, 2009), as mesmas são a seguir descritas de forma muito sucinta.

As RNA e as MVS permitem efetuar a previsão do valor de determinada variável através de um modelo formal, no qual, a contribuição das variáveis de entrada varia de acordo com a técnica usada. Nos problemas de regressão, quando é usada a técnica das regressões múltiplas, é obtida uma expressão para a variável dependente em função das outras variáveis. A aplicação das RNA e das MVS não origina quaisquer expressão final para a variável dependente.

A técnica de Redes Neuronais Artificiais utiliza uma arquitetura inspirada no cérebro humano. Os neurónios artificiais são interligados segundo uma dada configuração tendo cada ligação um peso ($w_{i,j}$) que representa a força do sinal enviado. Na Figura 1 está representada a configuração mais popular que tem a designação de Perceptrão Multicamada (Haykin, 1999). Existe ainda uma função de ativação que determina o nível de ativação do neurónio introduzindo uma componente de não linearidade no processo computacional (Haykin, 1999; Cortez, 2010). No presente trabalho foi usada a função de ativação logística ($1/(1+\exp(-x))$). O algoritmo de treino é aplicado ajustando sucessivamente os pesos tendo como critério de paragem o declive do erro nulo ou, quando isso não se verifica, o número máximo de iterações.

As Máquinas de Vetores de Suporte promovem a transformação dos dados de entrada num grande espaço característico m-dimensional, usando um mapeamento não linear, onde são selecionados vetores de suporte à previsão (Fig. 2) (Cortes e Vapnik, 1995; Cortez, 2010). As MVS procuram o melhor hiperplano de separação linear, relativo a um conjunto de vetores de suporte, no espaço característico. A transformação depende da função kernel $k(x,y)$ adotada. No presente trabalho foi usada a função kernel com base radial (Cortez, 2010):

$$K(x, x') = \exp\left(-\gamma \|x - x'\|^2\right), \quad \gamma > 0 \quad [1]$$

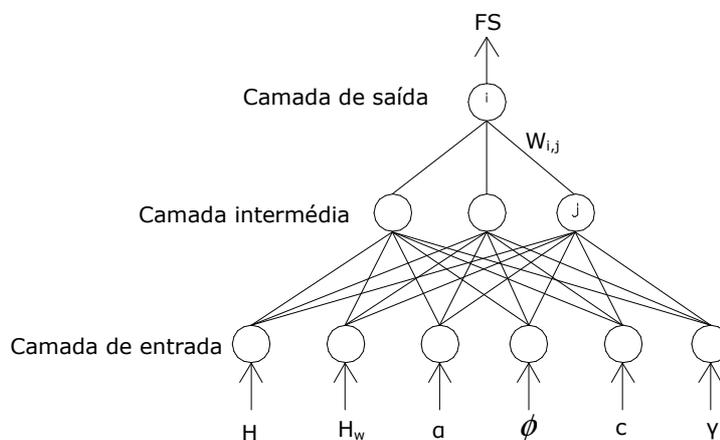


Figura 1 – Perceptrão multicamada

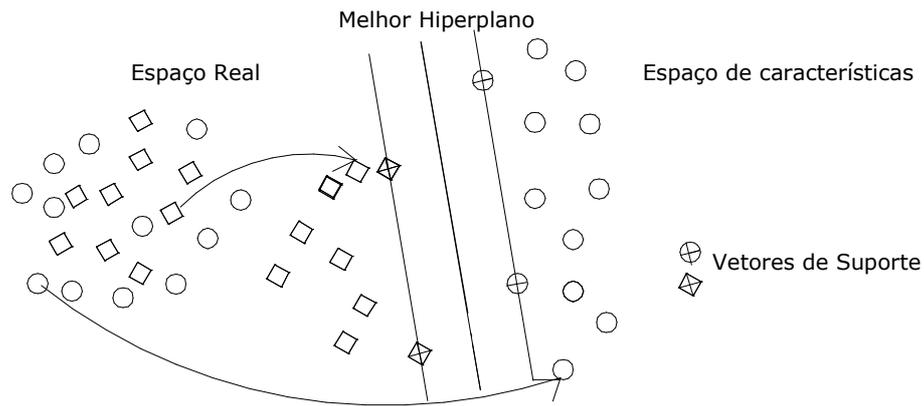


Figura 2 – Exemplo de uma transformação MVS

2.2 - Avaliação das técnicas

Para avaliar o desempenho das RNA e das MVS foram calculados o Desvio Absoluto Médio (DAM), a Raiz do Erro Quadrático Médio (REQM) e o coeficiente de correlação de Pearson (COR):

$$DAM = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad [2]$$

$$REQM = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad [3]$$

$$R = \frac{\sum_{i=1}^N (y_i - \bar{y}_i) \times (\hat{y}_i - \bar{\hat{y}}_i)}{\sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}}_i)^2}} \quad [4]$$

onde N designa o número de exemplos, y_i o valor desejado, \hat{y}_i o valor estimado pelo modelo em causa, \bar{y}_i a média dos valores desejados e $\bar{\hat{y}}_i$ a média dos valores estimados.

2.3 - Aplicação do processo de data mining

Para a aplicação do processo de Data Mining foi criada uma base de dados que foi construída com base nos resultados obtidos com o programa de cálculo automático SLOPE/W.

Foi usado a biblioteca RMiner (Cortez, 2010) no ambiente R (R Development Core Team, 2010). Esta biblioteca apresenta um conjunto coerente de funções que facilita o uso dos algoritmos de Data Mining nas tarefas de regressão e de classificação.

O ambiente R é um conjunto integrado de programas para a manipulação de dados, cálculos e traçado de gráficos que também permite a análise estatística. Como é um software aberto permite o desenvolvimento de pacotes de software envolvendo métodos numéricos e/ou estatísticos com determinado fim.

Foram estudados 501 taludes homogêneos através do método de Bishop modificado. Por isso, a base de dados foi constituída por 501 linhas tendo cada uma delas o registo dos parâmetros geométricos representados na Figura 3 (H , H_w e α), os parâmetros geotécnicos (peso volúmico $[\gamma]$, coesão $[c]$ e ângulo de atrito $[\Phi]$) e o fator de segurança calculado $[FS]$). Nos Quadros 1 e 2 são apresentadas algumas das estatísticas dos dados usados no treino e no teste dos modelos.

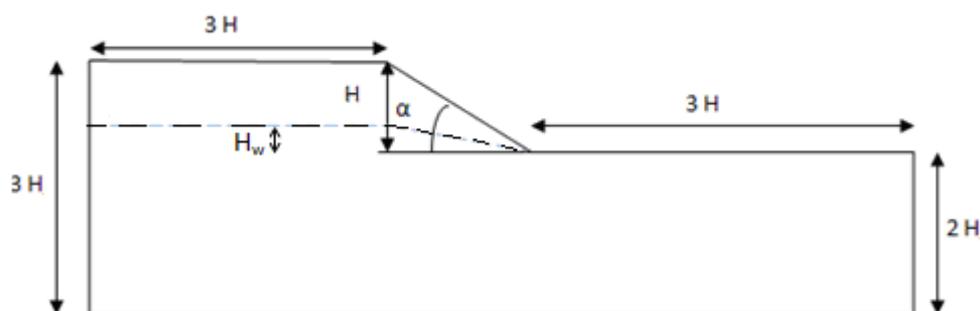


Figura 3 – Talude com os parâmetros geométricos usados

Quadro 1- Algumas estatísticas dos dados de treino

Atributo	H (m)	H _w (m)	α (°)	φ (°)	c (kPa)	γ (kN/m ³)	FS
Mínimo	10	0	40,04	28	6	16	0,81
Média	13,25	16	54,08	32,75	29,52	18,54	1,44
Máximo	19	5,48	69,94	37	49	21	2,81
Desvio padrão	2,48	3,66	8,57	2,90	11,92	1,75	0,42
Coef. Variação (%)	18,74	66,90	15,85	8,86	40,38	9,47	29,37

Quadro 2- Algumas estatísticas dos dados de teste

Atributo	H (m)	H _w (m)	α (°)	φ (°)	c (kPa)	γ (kN/m ³)	FS
Mínimo	15	0	40,27	28	5	16	0,80
Média	16,99	6,95	53,75	32,71	30,36	18,43	1,29
Máximo	19	18	69,65	37	49	21	2,14
Desvio padrão	1,49	4,72	8,36	2,97	11,81	1,61	0,31
Coef. Variação (%)	8,75	67,92	15,55	9,09	38,89	8,76	24,45

As RNA e as MVS foram testadas na previsão do fator de segurança sendo adotado um esquema de avaliação usando 10 execuções de uma validação cruzada *5-fold* (Efron e Tibshirani, 1993), onde os registros são divididos em 5 partes de igual tamanho. Sequencialmente, cada subconjunto é testado com o modelo ajustado com os registros sobranes. O desempenho global é dado pelo valor médio das métricas nas 10 execuções.

No problema de classificação, relacionado com a estabilidade (estável/instável) foi usado um esquema diferente, designado por "holdout". Nesse esquema os dados de treino foram divididos em dois conjuntos, contendo um deles 2/3 dos registros e o outro 1/3 dos registros. Na fase de treino o maior conjunto foi usado para o treino propriamente dito, enquanto o menor conjunto foi usado para o teste.

2.3.1 - Previsão do fator de segurança

As medidas de erro (DAM e REQM) e o coeficiente de correlação de Pearson (R) obtidos durante a fase de treino dos modelos e que permitem avaliar o desempenho das RNA e das MVS são apresentadas no Quadro 3.

Como se pode observar, as MVS apresentam melhor desempenho do que as RNA, tendo as menores medidas de erro e o maior coeficiente de correlação.

Quadro 3- Medidas de desempenho obtidas na fase de treino

	RNA	MVS
DAM	0,063	0,050
REQM	0,101	0,088
R	0,971	0,978

No presente trabalho foi desenvolvida uma ferramenta computacional, treinada com 334 registros, a qual permite generalizar o cálculo da previsão do fator de segurança em função dos valores das variáveis de entrada escolhidos pelo utilizador. Nas Figuras 4 e 5 apresentam-se as relações entre os fatores de segurança estimados para os 334 casos da base de dados de treino e os fatores de segurança efetivamente calculados, para as RNA e MVS. Nas Figuras 6 e 7 são apresentadas relações idênticas para os 167 dados de teste.

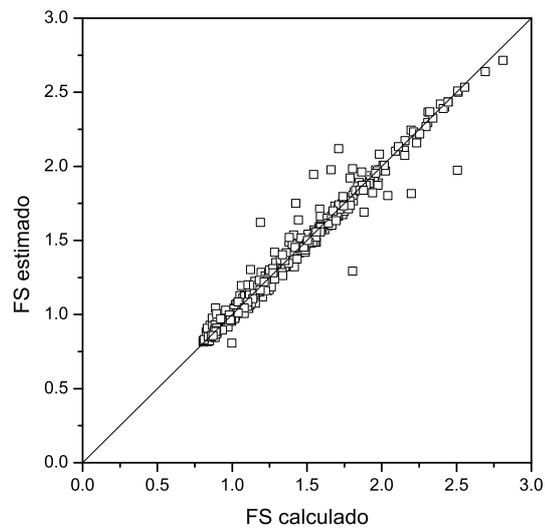


Figura 4 – Fatores de segurança calculados versus fatores de segurança estimados usando os dados de treino e as Redes Neurais Artificiais

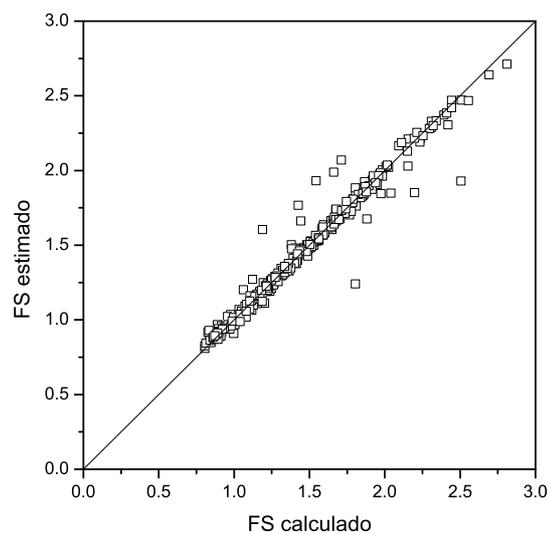


Figura 5 – Fatores de segurança calculados versus fatores de segurança estimados usando os dados de treino e as Máquinas de Vetores de Suporte

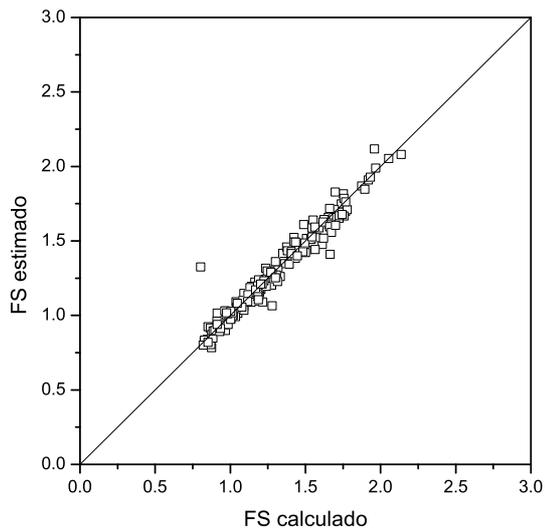


Figura 6 – Fatores de segurança calculados versus fatores de segurança estimados usando os dados de teste e as Redes Neurais Artificiais

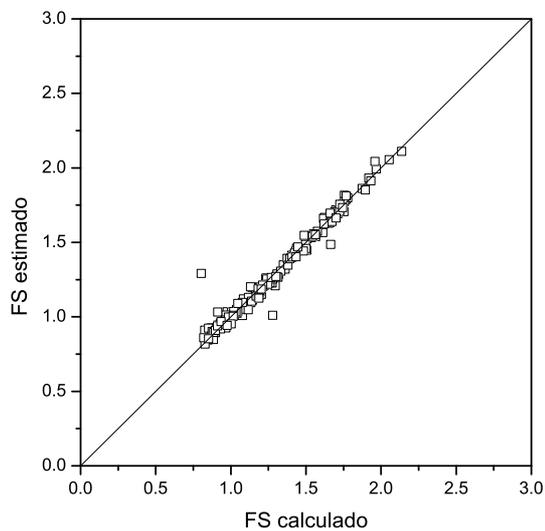


Figura 7 – Fatores de segurança calculados versus fatores de segurança estimados usando os dados de teste e as Máquinas de Vetores de Suporte

Como se pode ver nas Figuras 4 a 7 a mancha de valores situa-se bastante próxima da linha a 45°. Isto corresponde a um bom desempenho das RNA e MVS. A análise das Figuras 4 e 5 não permite concluir qual dos dois modelos tem melhor desempenho. No entanto, é visível que a mancha de pontos da Figura 7 se encontra mais concentrada em torno da linha a 45° do que a mancha de pontos da Figura 6. Isto quer dizer que as MVS têm um desempenho ligeiramente superior.

Para confirmar estas conclusões foram usados os dados de treino (Figuras 4 e 5) e os dados de teste (Figuras 6 e 7) para calcular o Desvio Absoluto Médio, a Raiz do Erro Quadrático Médio e o Coeficiente de Correlação de Pearson para as MVS e as RNA. Os resultados estão apresentados nos Quadros 4 e 5. Como se pode ver, o modelo que permite obter fatores de segurança mais próximos dos valores calculados é o que se baseia nas MVS, originando estas menores medidas de erro e maior coeficiente de correlação. No entanto, as RNA também têm um bom desempenho.

Quadro 4- Medidas de Erro e Coeficiente de Correlação de Pearson para as MVS e as RNA usando todos os dados de treino

	RNA	MVS
DAM	0,046	0,037
REQM	0,083	0,077
R	0,981	0,983

Quadro 5- Medidas de Erro e Coeficiente de Correlação de Pearson para as MVS e as RNA usando todos os dados de teste

	RNA	MVS
DAM	0,047	0,030
REQM	0,070	0,055
R	0,975	0,984

2.3.2 - Previsão da estabilidade

Para prever se o talude é estável ou instável as bases de dados foram ajustadas substituindo o fator de segurança dos taludes por "estável" quando FS é maior ou igual à unidade e "instável" quando FS é menor que 1. Com os 334 dados de treino as MVS obtiveram 97% de acertos enquanto as RNA acertaram em todos os registros. Com os 167 dados de teste, totalmente desconhecidos dos modelos, as MVS permitiram 91% de acertos enquanto as RNA registaram 88,6% de acertos. Portanto, também neste caso as MVS tiveram o melhor desempenho.

2.3.3 - Importância das variáveis de entrada

A ferramenta usada permite obter a importância das variáveis envolvidas no modelo de previsão determinada através do cálculo das variâncias.

A importância das variáveis de entrada é quantificada através de uma análise de sensibilidade (Kewley et al., 2000). Nessa análise é avaliada a resposta do modelo à variação dos parâmetros de entrada. Para avaliar a importância de um dado parâmetro faz-se variar o seu valor dentro da gama de valores que ele pode tomar ao mesmo tempo que se mantêm os valores médios de todos os outros parâmetros. Quando um parâmetro tem uma grande importância induz na saída do modelo uma alta variância. O contrário acontece para um parâmetro com pouca importância.

No Quadro 6 são apresentadas as importâncias dessas variáveis na previsão dos fatores de segurança e da estabilidade dos taludes. Consta-se que a coesão e a altura de água são os parâmetros mais relevantes na avaliação do fator de segurança e na previsão da estabilidade. A altura do talude, o ângulo de atrito e o peso volumico revelam-se pouco importantes para todos os modelos.

A importância dada à altura da água está de acordo com o esperado pois, como se sabe, a presença da água contribui para a diminuição da estabilidade dos taludes. A importância atribuída pelos modelos à coesão pode ser justificada pela grande variabilidade deste parâmetro. Na realidade, a coesão é o parâmetro de resistência que apresenta maior variabilidade.

Quadro 6- Importância das variáveis de entrada na estimativa do fator de segurança e na estabilidade (%)

	RNA		MVS	
	FS	Estabilidade	FS	Estabilidade
H	1,89	0	2,83	0,84
H _w	31,20	50	34,61	49,74
α	19,59	0	20,18	2,24
ϕ	1,89	0	2,39	0,20
c	44,84	50	39,15	46,95
γ	0,59	0	0,84	0,03

3 - CONCLUSÕES

Neste trabalho são comparados os desempenhos das RNA e das MVS na previsão dos fatores de segurança e da estabilidade de taludes.

Para a base de dados utilizada os métodos não lineares baseados em Máquinas de Vetores de Suporte conduziram a uma melhor estimativa do fator de segurança e efetuaram uma melhor avaliação da estabilidade dos taludes. A conclusão relacionada com a estimativa do FS vem confirmar a que já tinha sido obtida em estudos anteriores realizados pelo primeiro autor.

Constata-se que a coesão e a altura da água são os parâmetros com maior influência quer no fator de segurança quer na avaliação da estabilidade dos taludes.

REFERÊNCIAS

- Cortes, C. and Vapnik, V. (1995). Support Vector Networks. *Machine Learning*, 20(3): 273-297. Kluwer Academic Publishers.
- Cortez, P. (2010). Data Mining with Neural Networks and Support Vector Machines using the R/rminer Tool, In: P. Perner (Ed.), *Advances in Data Mining. Proceedings of 10th Industrial Conference on Data Mining*, lecture notes in artificial intelligence 6171 (pp. 572-583). Berlin: Springer.
- Craig, R. F. (2007). *Craig's Soil Mechanics*, 7th Edition, London: Spon Press.
- Efron, B. e Tibshirani, R (1993). *An Introduction to the Bootstrap*. Chapman & Hall, USA.
- Haykin, S. (1999). *Neural Networks - A Comprehensive Foundation*, 2nd edition, Prentice-Hall, New Jersey.
- Hechenbichler, K. e Schliep, K. (2004). Weighted k-Nearest-Neighbor Techniques and Ordinal Classification. Discussion Paper 399, SFB 386, Ludwig-Maximilians University Munich. URL: http://epub.ub.uni-muenchen.de/archive/00001769/01/paper_399.pdf.
- Kewley R, Embrechts M and Breneman C (2000) Data strip mining for the virtual design of pharmaceuticals with neural networks. *IEEE Transactions on Neural Networks*. 11(3): 668-679.
- Martins, F. F., Araújo, A. S. S. e Marques, R. F. P.(2008). Análise da estabilidade e otimização da geometria de taludes recorrendo a técnicas de inteligência artificial, *Proc. XI Congresso Nacional de Geotecnia*, Coimbra, Vol. 3, p. 131-138.
- Martins, F. F., Almeida, T. A. M. V. (2009). Análise da estabilidade de taludes recorrendo a ferramentas inteligentes, *3.ªs Jornadas Luso-Espanholas de Geotecnia sobre Geotecnia nas Infraestruturas Ferroviárias*, Madrid, 25-26 de junho de 2009, edição em CD-Rom.
- Martins, F. F., Gabriel, M. A. R. e Moreira, L. P. C. (2010). Avaliação da estabilidade de taludes através de técnicas de Data Mining, *XII Congresso Nacional de Geotecnia*, Guimarães, p. 813-822, Edição em CD Rom.
- Quinlan, J. (1986). Induction of Decision Trees. *Machine Learning*, 1: 81-106. Kluwer Academic Publishers.
- R Development Core Team (2010). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. <http://www.R-project.org>, ISBN 3-900051-00-3.
- Santos, M.; Azevedo, C. (2005). *Data Mining – Descoberta de Conhecimento em Bases de Dados*, FCA-Editora de Informática, Lisboa.